

Metodología para entrenamiento de máquina tipo jerárquico, para predecir el tipo de fallo y nivel de degradación en rodamientos, desde características de diferentes espacios de representación.

Jair Eduardo Ramirez Mosquera

Universidad Tecnológica de Pereira
Facultad de Ingeniería Eléctrica
Pereira, Risaralda, Colombia
2018

Metodología para entrenamiento de máquina tipo jerárquico, para predecir el tipo de fallo y nivel de degradación en rodamientos, desde características de diferentes espacios de representación.

Jair Eduardo Ramirez Mosquera

Proyecto presentado como requisito parcial para optar al título de:
Ingeniero Electricista

Director: PhD(C), M. Sc.Ing. Mauricio Holguín Londoño Profesor
Programa de Ingeniería Eléctrica Universidad Tecnológica de
Pereira

Facultad de Ingeniería Eléctrica
Pereira, Risaralda, Colombia
2018

Agradecimientos

Hoy, de todo corazón, quiero expresar mis más sinceros agradecimientos. Primero a Dios quien nunca me desamparo y fue mi guía, a mis padres por su amparo incondicional, a mi familia, a Nidia Graciela Collazos Agredo por su apoyo durante todos mis estudios; a los ingenieros Mauricio Holguín, director de mi trabajo de grado, y Andrés Felipe Calvo por el acompañamiento incondicional que me brindó.

Agradezco tambien a todos mis docentes, compañeros y demás personas que de una manera u otra estuvieron conmigo a lo largo de este proceso.

Contenido

Parte I. INTRODUCCION	10
1 Planteamiento del Problema.....	11
2 Justificación.....	12
3 Objetivos	13
3.1 Objetivo general	13
3.2 Objetivos específicos	13
Parte II. METODOS Y MATERIALES	14
4 Marco conceptual	15
4.1 Mantenimiento.....	15
4.1.1 Mantenimiento correctivo.	15
4.1.2 Mantenimiento preventivo	16
4.1.3 Mantenimiento predictivo	16
4.2 Rodamientos	17
4.2.1 Partes fundamentales de un rodamiento.....	18
4.2.2 Pista interna y externa	18
4.2.3 Elementos rodantes	19
4.2.4 Canastilla o jaula	19
4.3 Vibración	19
4.3.1 Señales de vibración.....	20
4.3.2 Técnicas de análisis de vibraciones.....	20
4.4 Máquinas de soporte vectorial SVM	21
4.4.1 Modelos de selección	22
4.4.2 Kernel	23
5 ESPACIOS DE REPRESENTACIÓN.....	23
5.1 Tiempo (t)	24
5.2 Frecuencia (f).....	24
5.3 Tiempo – Frecuencia (tf)	25
6 Análisis de datos.....	25

6.1	Coeficientes Cepstrales (MFCC).....	26
6.2	Transformada rapida de fourier (FFT).....	26
6.3	Método de Monte Carlo.....	27
6.4	Matriz de Confusión	27
6.4.1	Falsos Negativos (FN).....	28
6.4.2	Falsos Positivos (FP).....	28
6.4.3	Verdaderos Positivos (VP).....	28
6.4.4	Verdaderos Negativos (VN).....	29
6.5	Accuracy (Exactitud).....	29
6.6	Sensibilidad	29
6.7	Especificidad	29
6.8	Tasa de Falsos Negativos (TFN)	30
6.9	Tasa de Falsos Positivos (TFP)	30
PARTE III RESULTADO Y CONCLUSIONES		31
1	MARCO EXPERIMENTAL.....	32
2	RESULTADOS	35
2.1	Clasificación de falla	35
2.1.1	Análisis mediante función Kernel Gaussiano para tipos de falla representados en cuatro clases	36
2.1.2	Análisis mediante función Kernel Lineal para tipos de falla representados en cuatro clases	37
2.1.3	Análisis mediante función Kernel Polinomial para tipos de falla representados en cuatro clases	38
2.2	Nivel de severidad	38
2.2.1	Análisis mediante función Kernel Gaussiana.....	39
2.2.2	Analisis mediante función Kernel Lineal.....	40
2.2.3	Análisis mediante función Kernel Polinomial	41
2.3	Clasificación del Nivel de severidad para cada tipo de falla.	42
2.3.1	Falla en bola	42
2.3.2	Falla en pista interna	45
2.3.3	Falla en pista externa.....	47



2.4	Análisis de los resultados obtenidos en la simulación de fallas y niveles de severidad..	50
3	CONCLUSIONES	56
4	BIBLIOGRAFIA.....	57

Contenido ilustraciones

Ilustración 1 Principales tipos de rodamientos en la industria	18
Ilustración 2 Partes de un rodamiento	18
Ilustración 3 Hiperplano de separación binaria.....	22
Ilustración 4 Procesado FFT de una onda de vibración	25
Ilustración 5 Matriz de confusión para clasificador binario.....	28
Ilustración 6 Motor utilizado para la realización de la base de datos de los rodamientos	32
Ilustración 7 Distribucion de la base de datos	34
Ilustración 8 Base de datos de 12K relacionados a fallas en rodamientos instalados en el extremo de la transmisión.....	34
Ilustración 9 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Gaussiano	36
Ilustración 10 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Lineal	37
Ilustración 11 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Polinomial.	38
Ilustración 12 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Gaussiano	40
Ilustración 13 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Lineal.....	41
Ilustración 14 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Polinomial	42
Ilustración 15 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Gaussiano	43
Ilustración 16 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Lineal.....	44
Ilustración 17 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Polinomial	45
Ilustración 18 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Gaussiano	46
Ilustración 19 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Lineal.....	46
Ilustración 20 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Polinomial	47
Ilustración 21 Matriz de Confusión para análisis de niveles de severidad de falla en cara externa utilizando como función un Kernel Gaussiano	48
Ilustración 22 Matriz de Confusión para análisis de niveles de severidad de falla en cara externa utilizando como función un Kernel Lineal.....	49



Ilustración 23Matriz de Confusión para análisis de niveles de severidad de falla en cara externa
utilizando como función un Kernel Polinomial49

Contenido Tablas

Tabla 1 Representación de Falsos Negativos para todos los sistemas analizados	50
Tabla 2 Representación de Falsos Positivos para todos los sistemas analizados.....	51
Tabla 3 Representación de Verdaderos Positivos para todos los sistemas analizados.....	52
Tabla 4 Representación de Verdaderos Negativos para todos los sistemas analizados	53
Tabla 5 Representación de Sensibilidad para todos los sistemas analizados	54
Tabla 6 Representación de Especificidad para todos los sistemas analizados.....	55
Tabla 7 Representación de Accuracy para todos los sistemas analizados	55

Parte I. INTRODUCCION

1 Planteamiento del Problema

En la actualidad, el diagnóstico de fallas en la mayoría de los equipos que pertenecen a los diferentes campos del sistema energético, presenta un gran costo de inversión para mantenerlos operativos. Por este motivo, es de vital importancia buscar la forma más viable de reducir los costos de mantenimiento, a la vez que se mejora la vida útil [1]. Se han realizado estudios para determinar la distribución de los modos de fallo más comunes en motores eléctricos, los cuales representan un 30% del consumo energético, donde los rodamientos representan el 51% de los fallos y seguidos de lejos por los devanados con un 16%. De lo anterior, los rodamientos son cerca del 15,3% de los principales modos de fallo afectando el consumo energético mundial [2].

De acuerdo al concepto de la máquina ideal, ésta no genera vibración. Toda la energía que intercambia es utilizada para efectuar el trabajo para el cual fue diseñada. En la práctica, la vibración aparece producto de la transmisión normal de fuerzas cíclicas a través de los mecanismos. Los elementos de la máquina disipan una parte de la energía entregada, dando a la estructura una vibración característica [13].

Dentro de las herramientas para el monitoreo de señales está el análisis de las vibraciones mecánicas. Esta técnica se basa en el estudio de la información contenida por las señales de vibración en amplitud y frecuencia. En presencia de fallas, la señal de vibración contiene algunos armónicos los cuales se manifiestan en el espectro y pueden ser usados como indicadores de falla [3].

El nivel de vibración surge a raíz de diferentes factores, como el diseño, el montaje, la operación entre otros. El hecho de que una máquina esté íntimamente ligada con las vibraciones que ella produce, genera que la medición, el análisis de vibraciones, el análisis de señales y el análisis mecánico sean las herramientas básicas del mantenimiento predictivo por vibraciones mecánicas [13].

Los modelos basados en señales son importantes y potencialmente capaces de dar a conocer las fuentes componentes de las señales. La obtención de las señales del mundo real, generalmente tiene un alto costo, no obstante la caracterización de estas señales presenta dificultades en su tratamiento. Esto se puede notar significativamente en el manejo de grandes cantidades de datos que pueden provenir de espacios de representación y sus características, lo cual complica la capacidad de clasificar automáticamente [4].

Ahora bien, las vibraciones no son sólo propiedad de los sistemas mecánicos. Todos los sistemas físicos tienen la propiedad de vibrar y estas vibraciones serán el reflejo de su comportamiento dinámico. Por esta razón, las vibraciones emitidas tendrán una forma de representación que caracterizará al sistema del cual procede.

Los Modelos Ocultos de Markov (HMM) nacen como una metodología para tratar las señales de voz, las cuales se comportan como cuasi-estacionarias y se componen de procesos evolutivos. Este escenario coincide con el análisis de vibraciones, por lo que los HMM se presentan como una metodología ideal para reconocer estados latentes en las señales. Sin embargo, éstos presentan problemas de evaluación, secuencia de estados ocultos no cubiertos y resolución en escala cuando se trata de identificar gran cantidad de estados. Se hace necesario el uso de otras metodologías como Máquinas de soporte vectorial (SVM, en inglés) que posee mejores cualidades en la generalización con respecto a pequeños tamaños de muestra, además las SVM han logrado gran rendimiento en diferentes áreas de aplicación debido a su capacidad de análisis no lineal [5]. Los Modelos Ocultos de Markov Jerárquicos (HHMM, e inglés) [4], aportan gran avance a la investigación [6] debido a que permiten mediante un proceso estocástico subyacente, el cual puede ser observable mediante otro proceso estocástico, la indexación de datos embebidos [6].

Con este proyecto de grado se pretende buscar una solución a la pregunta de si es posible una implementación jerarquizada del entrenamiento de máquina con fines de diagnóstico, por medio de enfoques basados en HMM y/o SVM aplicadas al mantenimiento predictivo para encontrar el tiempo de vida útil restante de un rodamiento.

2 Justificación

Se han llevado a cabo, mediante continuas investigaciones, soluciones para detectar y diagnosticar fallos en rodamientos, enfocándose en la reducción de costos operativos. Estos estudios fueron realizados con parámetros obtenidos en pruebas para obtener el nivel de degradación de un rodamiento [5,7]. Para esto fueron utilizadas técnicas basadas en reconocimientos de patrones, las cuales transforman los elevados índices de datos ruidosos en datos útiles para el análisis.

Por medio de la simulación se puede encontrar un buen modelo de señal que brinde soluciones para la selección del modelo a usar en la caracterización de propiedades de dicha señal. Esto favorece el uso de máquinas de soporte vectorial, las cuales tienen gran capacidad de recibir diferentes tipos de señales y realizar una adecuada clasificación durante un tiempo estimado. Sin embargo, las SVM presentan limitación en cuanto a la caracterización [5]. Un modelo oculto de Markov anexo o en una etapa previa mejora la secuencia y el tiempo para la obtención de dichos datos y clasificación, debido a que éste, mediante observaciones y análisis de datos selecciona las mejores secuencias de los estados del modelo.

Dada la importancia y utilidad de los rodamientos en la industria, se ha impulsado la investigación sobre fallos, brindando gran cantidad de bases de datos relacionadas con el tipo de utilidad y la vida útil restante de un rodamiento. No obstante, para el entrenamiento de máquina, la caracterización de diferentes tipos y niveles de falla hacen que sea necesario el uso de modelos

estadísticos que brinden una alternativa más fiable, con menos nivel de incertidumbre y centrándose en la optimización del modelo, además preparando a la máquina para una detección más precisa de los diferentes tipos de falla. Gracias a que el modelo oculto de Markov posee unas bases matemáticas consolidadas, se puede caracterizar la relación estocástica entre características extraídas de datos monitoreados con respecto al estado de salud actual de un rodamiento o equipo.

Para dar solución a las falencias existentes en los HMM, como por ejemplo en el entrenamiento sobre un gran número de estados de fallo, en este proyecto de grado se dará respuesta a la pregunta mediante el entrenamiento de máquina, haciendo uso de un modelo estocástico de gran alcance como lo es el modelo oculto de Markov jerárquico u otros enfoques jerárquicos como SVM.

3 Objetivos

3.1 Objetivo general

Determinar una metodología para una estructura de entrenamiento de máquina tipo jerárquico, empleando HMM y/o HHMM y/o SVM, para predecir el tipo de fallo y nivel de degradación en rodamientos, al usar características de los espacios de representación del tiempo, frecuencia y tiempo-frecuencia.

3.2 Objetivos específicos

- Estudiar diferentes esquemas de entrenamiento de máquina tipo jerárquico, con base en HMM y/o HHMM y/o SVM.
- Hacer uso de los espacios de representación tales como: Tiempo, frecuencia y tiempo-frecuencia para caracterizar señales de vibración y su respectivo análisis.
- Implementar los esquemas jerárquicos usando como observaciones las características desde diversos espacios de representación con el fin de clasificar estados de degradación de rodamientos.
- Sintonizar los modelos y evaluar la confiabilidad de cada uno, con el fin de mejorar el diagnóstico del estado de fallo y nivel de degradación en rodamientos.

Parte II. METODOS Y MATERIALES

4 Marco conceptual

4.1 Mantenimiento

El mantenimiento es una disciplina que consiste en todas las actividades que deben ser desarrolladas en orden lógico, con el propósito de conservar en condiciones de funcionamiento seguro, eficiente y económico los equipos de producción, herramientas y demás propiedades físicas de las diferentes instalaciones de una empresa. Esta disciplina consiste en la realización de pruebas, inspecciones, ajustes, reemplazo, reinstalación, calibración, reparación y reconstrucción de elementos que son posibles causantes de fallas, basándose en el desarrollo de conceptos, criterios y técnicas que puedan garantizar que los activos a intervenir cumplan con las funciones para las cuales fueron diseñados y designados [17].

La efectividad con la que un equipo puede ser mantenido o restaurado para estar en condiciones de uso u operación, va ligado a la capacidad para restaurar efectivamente un producto. Lo que es denominado Mantenibilidad. Se ha demostrado que la seguridad de un puesto de trabajo y la mantenibilidad que se lleve a cabo en los equipos de trabajo, están directamente relacionados a la frecuencia con que se realiza el mantenimiento, debido a que es un factor importante en la posibilidad de que se produzca un accidente, afectando la mejora de los procesos productivos [17].

El mantenimiento, puede ser aplicado principalmente en 3 formas:

- Mantenimiento correctivo.
- Mantenimiento preventivo.
- Mantenimiento predictivo.

De estos tres tipos de mantenimiento, se han generado algunas variaciones que a su vez han sido utilizados en otras áreas más específicas.

4.1.1 Mantenimiento correctivo.

Es el conjunto de tareas o actividades destinadas a corregir los defectos que se van presentando en los distintos equipos después de la ocurrencia de una falla, considerándose la forma más básica de mantenimiento y consiste en localizar averías o defectos y corregirlos o repararlos. Este mantenimiento se realiza luego que ocurra una falla o avería en el equipo que por su naturaleza no pueden planificarse en el tiempo, presenta costos por reparación y de repuestos no presupuestados, pues puede implicar el cambio de algunas piezas del equipo en caso de ser necesario [18]. El

objetivo de este tipo de mantenimiento consiste en llevar a los equipos después de una falla a sus condiciones originales, por medio de restauración o sustitución de componentes o partes de equipos, debido a desgaste, daños o roturas [17].

4.1.2 Mantenimiento preventivo

Es el mantenimiento que tiene por misión mantener un nivel de servicio determinado en los equipos, programando las intervenciones de sus puntos vulnerables en el momento más oportuno [18].

Se ejecuta a frecuencias dinámicas, de acuerdo con las recomendaciones del fabricante, las condiciones operacionales y al historial de falla de los equipos [17]. El mantenimiento preventivo se realiza en equipos en condiciones de funcionamiento, por oposición al mantenimiento correctivo que repara o pone en condiciones de funcionamiento aquellos que dejaron de funcionar o están dañados.

El primer objetivo del mantenimiento es evitar o mitigar las consecuencias de los fallos del equipo, logrando prevenir las incidencias antes de que estas ocurran. Las tareas de mantenimiento preventivo pueden incluir acciones como cambio de piezas desgastadas, cambios de aceites y lubricantes, etc.

4.1.3 Mantenimiento predictivo

Es una actividad que consiste en el seguimiento organizado con medición periódica o continua de variables de estado en un sistema, máquina o equipo y su comparación con patrones preestablecidos con el fin de conocer e informar permanentemente del estado y operatividad de las instalaciones mediante el conocimiento de los valores de determinadas variables representativas, de tal estado y operatividad [17]. Para aplicar este mantenimiento, es necesario identificar variables físicas como temperatura, vibración, consumo de energía, etc. cuya variación sea indicativa de problemas que puedan estar apareciendo en el equipo. Es el tipo de mantenimiento más tecnológico, pues requiere de medios técnicos avanzados, y en ocasiones, de fuertes conocimientos matemáticos, físicos y/o técnicos [18].

La ventaja más notable en el mantenimiento preventivo es que las fallas se detectan en sus etapas iniciales generando un amplio margen de tiempo para la programación de acciones correctivas, en paros programados y bajo condiciones controladas que minimicen los tiempos muertos garantizando una mejor calidad en las reparaciones.

El requisito para que se pueda aplicar una técnica predictiva es que el fallo incipiente genere señales o síntomas de su existencia, tales como alta temperatura, ruido, ultrasonido, vibración, partículas de desgaste o alto amperaje, entre otras.

Las técnicas para detección de fallos y defectos en maquinaria varían, desde la utilización de los sentidos humanos (oído, vista, tacto y olfato), hasta la utilización de datos de control de proceso y de control de calidad, el uso de herramientas estadísticas y técnicas de moda como el análisis de vibración, la termografía, la tribología, el análisis de circuitos de motores y el ultrasonido.

4.2 Rodamientos

Los rodamientos son elementos con múltiples aplicaciones en las máquinas Rotativas. Su capacidad de carga y confiabilidad son importantes para el desempeño general de la máquina. Además, sin estos sería imposible ejecutar el movimiento para el desarrollo de cualquier actividad. Estos elementos forman puntos de apoyo en ejes rotativos, tienen la función de soportar el peso de los ejes, no obstante sirven como guía de rotación. Los rodamientos han tenido una gran influencia en la humanidad, ya que éstos han sido un factor importante para el desarrollo tecnológico de hoy en día [17].

Un rodamiento puede ser axial, radial, o una combinación de ambos. Ésto se determina según el tipo de esfuerzo que va a soportar en la máquina.

El rodamiento radial, es usado en aplicaciones en las que el cojinete se encuentra expuesto a esfuerzos radiales. Estos esfuerzos son aquellos que se encuentran en dirección ortogonal a la dirección que pasa por el centro del eje, como por ejemplo una rueda. Un rodamiento de tipo axial se usa en aplicaciones en las que se presentan esfuerzos en la misma dirección del eje. Un ejemplo de estos son la bisagras de puertas y ventanas [19].

En forma general, los rodamientos se encuentran clasificados en dos grupos. Rodamientos de rodillos cilíndricos y esféricos. Los rodamientos de rodillos cilíndricos tienen una excelente resistencia a las sobrecargas instantáneas y los choques, permitiendo una simplificación de los montajes gracias a sus elementos separables. Para determinados tipos, permiten un desplazamiento axial o bien una carga axial débil. Los rodamientos de bolas son los más comunes y los más utilizados en las aplicaciones del mercado, siendo capaces de soportar cargas axiales y radiales. Su característica principal es la velocidad de giro, siendo esta superior que en otros tipos de rodamiento.

En la ilustración 1 se observa la clasificación de los rodamientos, donde cabe notar que para cada tipo de rodamiento existen cojinetes de bolas y de rodillos cilíndricos.

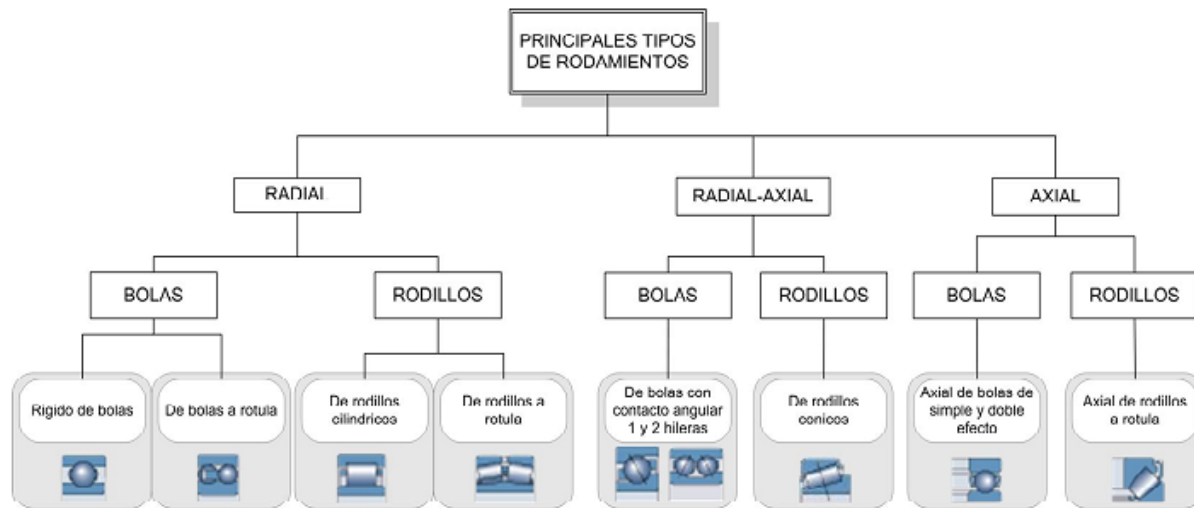


Ilustración 1 Principales tipos de rodamientos en la industria

4.2.1 Partes fundamentales de un rodamiento

Las partes de un rodamiento son:




Ilustración 2 Partes de un rodamiento

4.2.2 Pista interna y externa

Son los elementos que se fijan mutuamente a los dos elementos que acopla el rodamiento. La pista interior se acopla con el eje mientras que la pista exterior se acopla con el alojamiento del

rodamiento, pero esta conilustración puede cambiar dependiendo de la construcción del rodamiento Siempre una de las dos pistas permanecerá fija mientras la otra gira. Los dos aros de las pistas tienen unas gargantas, denominadas caminos de rodadura por donde rodarán los elementos rodantes [17].

4.2.3 Elementos rodantes

Los elementos rodantes del rodamiento pueden ser rodillos, bolas, esferas, agujas o conos. Por lo general, estos elementos resultan de una aleación de cromo y de acero de gran pureza, que a su vez también se utilizan materiales especiales como los plásticos y la cerámica. Estos elementos giran sobre su propio eje produciendo una rodadura sobre los caminos de los rodamientos, permitiendo el giro relativo entre los dos aros y de las dos piezas que se encuentran unidas [20].

Los elementos rodantes se caracterizan por girar encima de los caminos de la rodadura, las cuales también se conocen con el nombre de pistas y están conformados mayormente en los anillos, manteniéndose divididos y guiándose a través de la jaula [17].

4.2.4 Canastilla o jaula

La jaula es una parte del rodamiento, que tiene como propósito mantener los elementos rodantes en la posición adecuada, separándolos uno del otro y a vez guiándolos para evitar que los elementos rodantes se desmonten, o choquen entre ellos [20]. La jaula se compone de distintos materiales, entre los cuales es más común encontrar latón, plástico y acero. Se pueden hacer y fabricar jaulas de metal sólido a través de técnicas de mecanizado, mientras que para hacer jaulas prensadas se utilizan las láminas de acero como material de construcción [21].

4.3 Vibración

La vibración es una oscilación mecánica en torno a una posición de equilibrio con relación al tiempo [23]. La posición de equilibrio es a la que se llega cuando la fuerza que actúa sobre el eje sea cero. Este tipo de vibración se llama cuerpo entero, lo que quiere decir que todas las partes del cuerpo se mueven juntas en la misma dirección en cualquier momento [22]. La característica fundamental de la vibración es que es periódica, siendo frecuente el movimiento armónico simple, por lo que este movimiento adquiere una importancia en los estudios vibratorios [17].

La vibración es el resultado de fuerzas dinámicas en las máquinas o estructuras que tienen partes en movimiento o sometidas a acciones variables. Las diferentes partes de la máquina vibrarán con distintas frecuencias y amplitudes. La vibración puede causar molestias y fatiga. A menudo es la última responsable de la "muerte" de la máquina. Además, muchas veces es un efecto molesto y destructivo de un proceso útil, aunque en otros casos es generada intencionadamente para desarrollar una tarea [23].

Actualmente, el estudio y análisis de las vibraciones mecánicas ha adquirido gran importancia en la supervisión de los sistemas mecánicos, sobre todo de elementos de tipo rotativo. Independientemente de los planes de mantenimiento correctivo y preventivo, el plan de mantenimiento predictivo se basa, principalmente, en el estudio de las vibraciones mediante la instalación de sensores que permiten detectar vibraciones fuera de rango [17].

4.3.1 Señales de vibración

En un sistema de mantenimiento predictivo mediante análisis de vibraciones se estudia la evolución del comportamiento vibracional de las máquinas, de manera que identificando las causas se encuentra el momento oportuno para tomar una acción correctiva, por ejemplo un cambio de rodamiento [17]. La característica principal en una señal de vibración en el dominio del tiempo son las ondas sinusoidales. Estas ondas representan las oscilaciones puras y presentan amplitud y fase. La amplitud enfocada desde las vibraciones es la cantidad de movimiento de una masa partiendo desde una posición neutral. La fase es la medida de tiempo entre la separación de dos señales vibratorias.

Se define a la señal de vibración mecánica como el movimiento oscilatorio de una máquina, de una estructura o de una parte de ella, alrededor de su posición de reposo original. Las características de la onda son frecuencia, amplitud y fase. Éstas se expresan en la siguiente ecuación:

$$D(t) = D_0 \sin(2\pi f t + \Phi) \text{ (Ecuación 4.3.1).}$$

Donde D_0 es el desplazamiento máximo o desplazamiento pico; f es la frecuencia; Φ corresponde a la fase; y t al tiempo. Esta onda es medida a través de un transductor o sensor de vibraciones.

4.3.2 Técnicas de análisis de vibraciones

Para obtener un análisis de vibraciones se debe emplear uno de los dos métodos que se muestran a continuación.

4.3.2.1 Medición en la amplitud de la vibración.

Mediante esta técnica se logra obtener un valor global del desplazamiento o velocidad de la vibración. En el momento en el que la vibración sobrepasa el valor preestablecido, la máquina debe ser revisada. Este método únicamente arroja señal de que hay problemas, pero no es posible determinar por esta técnica donde se encuentra ubicado el problema.

4.3.2.2 Analizador del espectro de vibración.

En esta técnica, la vibración se descompone según su frecuencia. A diferencia del caso anterior, por este método si se puede determinar donde se encuentra ubicado el problema, debido a que permite analizar el nivel de vibración en cada una de las frecuencias para determinar la causa de la anomalía.

4.4 Máquinas de soporte vectorial SVM

Las Máquinas de Soporte Vectorial (SVM) son un método de clasificación de vanguardia introducido en el año 1992 por Boser, Guyon y Vapni [26], las cuales fueron introducidas en diferentes aplicaciones como bioinformática, visión artificial, reconocimiento de caracteres, categorización de texto e hipertexto, clasificación de proteínas, procesamiento de lenguaje natural, análisis de series temporales, entre otras. De hecho, desde su introducción, han ido ganando un merecido reconocimiento gracias a sus sólidos fundamentos teóricos [27].

Dentro de la tarea de clasificación, las SVM pertenecen a la categoría de los clasificadores lineales, debido a que inducen hiperplanos, ya sea en el espacio original de los datos de entrada, si éstos son separables o cuasi-separables (ruido), o en un espacio transformado (espacio de características). La idea es seleccionar un hiperplano de separación que equidista de los datos más cercanos de cada clase para conseguir lo que se denomina un margen máximo a cada lado del hiperplano como se observa en la ilustración 3. Además, a la hora de definir el hiperplano, sólo se consideran los datos de entrenamiento de cada clase que caen justo en la frontera de dichas márgenes. Estos datos reciben el nombre de vectores soporte. Desde un punto de vista práctico, el hiperplano separador de margen máximo ha demostrado tener una buena capacidad de generalización, evitando en gran medida el problema del sobreajuste a los datos de entrenamiento [27].




Ilustración 3 Hiperplano de separación binaria

Si los datos no son separables linealmente en el espacio original, se hace la búsqueda de un hiperplano de separación de muy alta dimensión. Generalmente son usadas las funciones Kernel para encontrar dichos planos. Es necesario tener una adecuada comprensión del funcionamiento de las SVM debido a que es necesario tomar decisiones como cuál es el Kernel adecuado y la etapa de preprocesamiento de los datos, ya que una mala elección de esta información puede generar un bajo rendimiento en el resultado de la SVM [26].

La característica fundamental de las SVM parte del concepto de separación óptima, donde este tipo de algoritmo consiste en buscar el hiperplano que tenga la máxima distancia (margen) con los puntos que estén más cerca de él mismo. Por eso también a veces se les conoce a las SVM como clasificadores de margen máximo. De esta forma, los puntos del vector que son etiquetados con una categoría estarán a un lado del hiperplano y los casos que se encuentren en la otra categoría estarán al lado contrario.

Para obtener una adecuada margen se debe considerar una regresión logística, donde la probabilidad $p(y = 1|x; \theta)$ es modelada por $h_{\theta}(x) = g(\theta^T x)$. Entonces, se predice “1” en una entrada x , si y solo si $\theta^T x \geq 0,5$, o equivalente si y solo si $\theta^T x \geq 0$.

4.4.1 Modelos de selección

La precisión de un clasificador está relacionada directamente con los hiperparámetros de la SVM. Cuando se trabaja con una clase lineal, el único plano que se debe sintonizar es la constante de la margen suave de la SVM. Para las clases polinomial y gaussiana el espacio de búsqueda es bidimensional. El método estándar para explorar este espacio bidimensional es mediante la

búsqueda de cuadrículas donde los puntos de la cuadrícula son elegidos mediante una escala algorítmica, y la precisión del clasificador es estimada para cada uno de los puntos de la ésta.

Una propiedad interesante de las SVM es que existe una gama de valores de parámetros que producen un rendimiento óptimo de las clases. Ésto se ve reflejado mediante una equivalencia de puntos a lo largo de una arista en el espacio de parámetros causando la disminución de la curvatura del límite de decisión [30].

4.4.2 Kernel

Un Kernel es una función K , tal que para todo $x_1, x_2 \in X$ $K(x_1, x_2) = \phi(x_1) \cdot \phi(x_2)$ el cual, mediante el producto punto calcula la similitud de dos puntos de datos en el espacio de características. Es importante una apropiada selección de la función Kernel, debido a que ésta define el espacio de características en el que el entrenamiento clasifica los datos. El Kernel expresa conocimiento previo sobre el fenómeno que se está modelando, codificado como una medida de similitud entre dos vectores.

En las SVM se puede ubicar un hiperplano de separación en el espacio de características sin haber clasificado puntos de este espacio tan siquiera. Solo es necesario definir una función Kernel, que desempeñe la función del producto de puntos en el espacio de características [30].

5 ESPACIOS DE REPRESENTACIÓN

Una señal se puede representar de muchas formas. Si se considera la representación vectorial, se puede hacer uso de diferentes espacios vectoriales. Estos espacios de representación se constituyen mediante el proceso de modelamiento de la señal bajo una variable espacial determinada. Este procesamiento de la señal es de suma importancia ya que determina los parámetros base para el desarrollo de estudio de características del modelo. Otra forma en la que se puede representar una señal es por medio de la frecuencia. Ésto se obtiene haciendo uso de la transformada de Fourier ya que utiliza una base formada de funciones trigonométricas como el seno y coseno en distintas frecuencias. Algunos de los espacios de representación son los siguientes [17].

5.1 Tiempo (t)

Entre los espacios de representación, el tiempo está catalogado como la representación natural de una señal de vibración, debido a que está compuesta por una señal (y) que puede ser analizada como una suma de funciones seno compuesta por diferentes señales que provienen del sistema, la cual compone frecuencias (f_i), amplitudes (A_i) y fases (φ_i). Cada mecanismo en particular esta representado por una senoide.

$$y(t) = \sum_i A_i \sin(2\pi f_i t + \varphi_i) \text{ (Ecuación 5.1)}$$

Donde el subíndice (i) representa cada elemento que hace parte de la máquina. Cuando se pasa del dominio del tiempo a otro espacio de representación, es necesario hacer uso de funciones ortogonales que permitan transformar la señal $y(t)$ a otro espacio de representación [22].

5.2 Frecuencia (f)

El dominio de la frecuencia es otra forma de representación. Es utilizada en la mayoría de las aplicaciones que involucran señales de vibración debido a la naturaleza de la misma. Para ello se hace uso de la gráfica de espectro la cual relaciona la amplitud frente a la frecuencia. El espectro es la mejor herramienta que existe en la actualidad para el análisis de maquinaria. Fue precisamente el matemático francés Jean Baptiste Fourier quien encontró la forma de representar una señal compleja en el dominio del tiempo por medio de series de curvas sinusoidales con valores de amplitud y frecuencia específicos.

La herramienta denominada analizador de espectros trabaja con la transformada rápida de Fourier (FFT) para capturar una señal de la máquina y así calcular todas las series de señales sinusoidales que contienen la señal compleja y por último mostrarlas de forma individual en una gráfica de espectros como se observa en la ilustración 4. Marcos Gestal en su libro *Introducción a los Algoritmos genéticos y la Programación genética* afirma que se usa el método Nyquist para calcular la densidad espectral de potencia, el cual hace uso de transformadas como FFT, donde la señal resultante es un conjunto de componentes de frecuencia que comprende un rango desde la frecuencia 0 hasta $f_s/2$, siendo f_s la frecuencia de muestreo de la señal [31].

Una señal discreta en tiempo será bien representada si la frecuencia de muestreo es igual o superior a la frecuencia máxima del sistema. Para llevar la señal en el tiempo al dominio espectral, en este trabajo, es empleada la FFT [22].




Ilustración 4 Procesado FFT de una onda de vibración

5.3 Tiempo – Frecuencia (tf)

Una representación Tiempo – Frecuencia (tf) está conformada por una superficie cuyos ejes son el tiempo y la frecuencia. Entre estos ejes se encuentran relacionados pares de t-f, los cuales disponen de un valor de amplitud denominados energía del punto. Con estos puntos se puede conocer la forma de la señal en el plano t-f y obtener el valor de la concentración de intensidad en cada punto de una distribución global para apreciar la evolución de dicha amplitud tanto en el tiempo como en la frecuencia, aprovechando las características producidas por la concentración de la energía en dos dimensiones (tiempo y frecuencia) en vez de solo una (tiempo o frecuencia).

Las t-f se encuentran distribuidas en dos formas, la paramétrica que es aquella que utiliza la información de la señal junto con modelos de regresión lineal para obtener un mapa en 2D, y la no paramétrica que realiza una transformación de la señal por tramos, mediante ventanas de selección [17].

6 Análisis de datos

En este capítulo se encuentran relacionados todos aquellos métodos utilizados para el análisis y procesamiento de datos tales como los coeficientes cepstrales, Transformadas de Fourier, Metodo de Monte Carlo entre otros.

6.1 Coeficientes Cepstrales (MFCC)

Mel-frequency cepstral coefficients (MFCC) son coeficientes para la representación de señales basados en la percepción auditiva humana. Estos surgen de la necesidad en el área de reconocimiento automático del audio. Los MFCC son una representación definida como los cepstrum reales de una señal ventaneada a corto tiempo obtenida mediante la transformada rápida de Fourier (FFT). La diferencia de los MFCC con los cepstrum reales es que se usa una escala no lineal de frecuencia. Así, los MFCC pueden ser considerados como una aproximación al comportamiento del sistema auditivo humano [32], partiendo de que el sistema auditivo funciona como un banco de filtros en las que el módulo de amplitud decae exponencialmente, y las frecuencias centrales de cada filtro están espaciadas de forma creciente y logarítmica. Los MFCC intentan emular este comportamiento mediante un banco de filtros que usa la escala Mel para la determinación de las frecuencias centrales de cada filtro. La energía que pasa por cada filtro corresponde a cada MFCC de la señal [32]. Una gran ventaja de los MFCC es que constituyen una transformación homomórfica, de forma que, en teoría las convoluciones y efectos de filtrado en el dominio temporal se convierten en sumas en el dominio espectral [22]. Para poder convertir una frecuencia f en Hercios a una frecuencia m en escala Mel, se aplica la siguiente ecuación [22]:

$$m = 1127 * \log_e\left(1 + \frac{f}{700}\right) \quad (\text{Ecuación 6.1.1})$$

Donde al despejar f se puede obtener la siguiente ecuación:

$$f = 700 * \left(e^{\frac{m}{1127}} - 1\right) \quad (\text{Ecuación 6.1.2})$$

6.2 Transformada rápida de fourier (FFT)

La transformada rápida de Fourier, conocida por sus siglas en ingles (FFT Fast Fourier Transform) es un eficiente algoritmo que permite calcular la transformada de Fourier de forma discreta (DTF) y su inversa. En la mayoría de las aplicaciones, todas la señales se representan mediante la suma de series de Fourier. Por medio de un adecuado análisis de las DTF se puede obtener una representación de Fourier para las señales de duración finita. Cuando se trabaja en tiempo real, el cálculo podría resultar demasiado lento y los recursos disponibles podrían ser insuficientes. Es aquí donde entra en juego la FFT debido a que este método elimina una gran parte de los cálculos repetitivos a los que se ve sometida la DTF, por lo que logra un cálculo más rápido a menor costo [33].

El algoritmo de la FFT fue originalmente inventado por Carl Friedrich Gauss en 1805. Diferentes versiones del algoritmo fueron descubiertas a lo largo de los años, pero la FFT no se hizo popular sino hasta 1965, con la publicación de James Cooley y John Tukey, quienes reinventaron el algoritmo al describir como ejecutarlo de forma eficiente en una computadora [33].

La FFT parte del concepto de la DTF, donde al definir un número complejo $W = e^{j2\pi/N}$ se obtiene como expresión de la Transformada Discreta de Fourier mostrada a continuación [33].

$$H_n = \sum_{k=0}^{N-1} W^{nk} h_k \quad (\text{Ecuación 6.2})$$

Donde el número de multiplicaciones a realizar es del orden de N^2 . No obstante Hn se puede calcular con un número de multiplicaciones del orden de $N \cdot (N/2)$, mediante el algoritmo conocido como la transformada rápida de Fourier, FFT, ya que la reducción de tiempo de cálculo es muy grande [17].

6.3 Método de Monte Carlo

El método de Monte Carlo es una técnica numérica para calcular probabilidades y otras cantidades relacionadas. Esta técnica es usada para aproximar expresiones matemáticas complejas y/o costosas de evaluar con exactitud. Este método es llamado así en referencia al Casino Monte Carlo ubicado en la Monaco, debido a que esta es la capital del juego de azar y básicamente la ruleta es un generador simple de números aleatorios [35].

6.4 Matriz de Confusión

Una matriz de confusión es una herramienta en la cual se puede visualizar el desempeño de un algoritmo que se emplea en aprendizaje supervisado. Esta herramienta puede ser aplicada en problemas de n número de clases. Es una matriz de $n \times n$, donde las filas son nombradas según las clases reales y las columnas, según las clases previstas por un modelo de entrenamiento. Esta herramienta sirve para mostrar de forma explícita al momento de realizar el modelo de entrenamiento, cuando una clase es confundida por otra. Por eso permite trabajar de forma separada con distintos tipos de error.

Tipos de diagnosticos		ENTRENAMIENTO DE LA SVM	
		POSITIVO	NEGATIVO
CARACTERISTICA REAL	POSITIVO	Verdadero Positivo	Falso negativo
	NEGATIVO	Falso positivo	verdadero negativo

Ilustración 5 Matriz de confusión para clasificador binario

En la ilustración 5 se observa la representación de una matriz de confusión, donde la diagonal principal contiene la suma de todas las predicciones correctas. Los elementos fuera de la diagonal reflejan los errores del clasificador, sin embargo cuando las distintas clases están muy desequilibradas la forma del clasificador se puede tornar un poco inútil, debido a que se podría inclinar hacia la clase con más valores. Cuando se mide la precisión del algoritmo de esta forma no se distingue entre los errores de tipo falso positivo y falso negativo, y se asume que ambos tienen la misma importancia.

6.4.1 Falsos Negativos (FN)

Para el caso de la ilustración 5, se considera falsos positivos a todas las pruebas que la SVM considera como modelos negativos, pero en realidad pertenecen al modelo positivo.

6.4.2 Falsos Positivos (FP)

Como se observa en la ilustración 5, se considera falso negativo al conjunto de pruebas que fueron caracterizadas como modelo positivo, pero que en realidad pertenecían al modelo negativo.

6.4.3 Verdaderos Positivos (VP)

Son denominados Verdaderos positivos al conjunto de pruebas acertadas, para el caso de la ilustración 5, son aquellas que tanto en el entrenamiento de la SVM como en el modelo real fueron positivos.

6.4.4 Verdaderos Negativos (VN)

Se llaman verdaderos negativos al conjunto de pruebas acertadas. Para el caso de la ilustración 5 son todos aquellos que a diferencia del verdadero positivo, la respuesta debido al entrenamiento de la SVM es negativo tal como en el modelo real.

6.5 Accuracy (Exactitud)

La exactitud es denominada como la razón entre el número de unidades muestreadas que fueron clasificadas de forma correcta, (elementos de la diagonal de la matriz de confusión) y el número total de elementos que forman parte del mapa como se muestra en la ecuación 6.5.

$$Exactitud = VP + \frac{VN}{VP+VN+FN+FP} \quad (\text{Ecuación 6.5})$$

6.6 Sensibilidad

La sensibilidad se puede definir como la capacidad que tiene un sistema de clasificación de dar como datos positivos aquellos valores que en realidad pertenecen a esta clase. El valor que puede asumir la sensibilidad varía entre 0 y 1 o 0 y 100%, es decir, mientras más grande sea el valor de la sensibilidad indica que hay una mejor capacidad de detectar los casos positivos en esta prueba como se muestra en la ecuación 6.6.

$$Sensibilidad = \frac{\text{Verdaderos Positivos}}{\text{Total de casos positivos}} \times 100\% = \frac{VP}{VP+FN} \times 100\% \quad (\text{Ecuación 6.6})$$

6.7 Especificidad

A diferencia de la sensibilidad, la especificidad se puede definir como la capacidad que tiene un sistema de clasificar como negativos a todos los valores que en realidad pertenecen a la clase negativa. Su valor varía igual que en el caso de la sensibilidad entre 0 y 1 o 0 y 100%, indicando que mientras más alto sea el valor de la especificidad mayor será la capacidad de un sistema de clasificar los valores negativos de la prueba como se observa en la ecuación 6.7.

$$Especificidad = \frac{Verdaderos\ Negativos}{Total\ casos\ Negativos} \times 100\% = \frac{VN}{VN+FP} \times 100\% \quad (\text{Ecuación 6.7})$$

6.8 Tasa de Falsos Negativos (TFN)

Se denomina tasa de falsos negativos al cociente entre el número de registros con falla incorrectamente clasificados y el número total de datos normales o sin falla. A continuación se relaciona la ecuación 6.8.

$$TFN = \frac{VN}{VN+FP} \quad (\text{Ecuación 6.8})$$

6.9 Tasa de Falsos Positivos (TFP)

Se denomina tasa de falsos positivos al cociente entre el número de registros normales incorrectamente clasificados y el número total de datos normales o sin falla. El método por el cual se puede calcular esta relación esta dada por la ecuación 6.9.

$$TFP = \frac{FP}{VN+FP} \quad (\text{Ecuación 6.9})$$

PARTE III RESULTADO Y CONCLUSIONES

1 MARCO EXPERIMENTAL

Para la realización de este trabajo de grado se utilizó como base de datos, la información de pruebas de fallas sembradas en rodamientos, almacenados en la plataforma del “Centro de Datos de Rodamientos” de CASE WESTERN RESERVE UNIVERSITY. Esta base de datos contempla tanto los rodamientos normales como los defectuosos, y fue obtenida mediante experimentos llevados a cabo en un motor Reliance Electric de 2 hp, garantizando unas condiciones reales de prueba, las cuales se encuentran documentadas cuidadosamente para cada experimento [36].

En el motor se instalaron rodamientos que contenían fallas generadas mediante el mecanismo de electrodescarga (EDM). Estas fallas que fueron introducidas de forma separada en la pista interior, la pista exterior y elemento rodante (bola) tienen una variación entre 0.007 pulgadas y 0.040 pulgadas. Los rodamientos defectuosos fueron reinstalados en la prueba del motor y en la prueba de potencia motorizada, donde las velocidades del motor variaron entre 1797 RPM Y 1720 RPM.



Ilustración 6 Motor utilizado para la realización de la base de datos de los rodamientos

Para la realización de la prueba se utilizó un motor Reliance Electric de 2 hp, el cual se encuentra instalado en la parte izquierda de la ilustración 6, un transductor / codificador el cual se observa en el centro de la ilustración 6, y un dinamómetro que se encuentra instalado en la parte derecha del transductor [34].

El eje del motor se encuentra soportado sobre los rodamientos de prueba. Las fallas de punto único se introdujeron mediante descarga eléctrica con diámetros de 7, 17, 21, 28 milipulgadas. Los rodamientos SKF se usaron para las fallas de 7, 14 y 21 milipulgadas de diámetro, mientras que para las fallas de 28 milipulgadas fueron utilizados rodamientos del fabricante NTN [34].

Los datos de vibración se obtuvieron utilizando acelerómetros, que se unieron a la carcasa con bases magnéticas. Los acelerómetros se colocaron en la posición de las 12 en punto en el extremo de la carcasa del motor. Las señales de vibración se recogieron usando un grabador DAT de 16 canales y se procesaron posteriormente en un entorno Matlab. Todos los archivos de datos están en formato Matlab (*.mat). Los datos digitales se recolectaron a 12,000 muestras por segundo, mientras que para las fallas en los rodamientos del extremo de la transmisión fueron recolectados a una velocidad de 48,000 muestras por segundo. Los datos de velocidad y potencia se recogieron usando el transductor / codificador de par y se registraron a mano [34].

Las fallas externas de la pista de rodadura son fallas estacionarias, por lo que la ubicación de la falla está relacionada con la zona de carga del rodamiento. Para cuantificar este efecto, a las 6 en punto (ortogonal a la zona de carga), y experimentos 12 en punto.

Para el entrenamiento de la SVM se utilizó la base de datos que se muestra en la ilustración 8. Luego de ser descargada de la plataforma, se procedió a usar la herramienta Matlab para extraer las características de la base de datos [34].

La base de datos se encuentra conformada por cuatro carpetas que representan los tipos de fallos, donde en cada una de ellas están:

- Fallo en elemento rodante (Ball).
- Fallo en pista interna (Inner).
- Fallo en pista externa (Outer).
- Sin falla (Normal).

Cada una de las carpetas que relaciona los fallos, contienen tres niveles de severidad (N1, N2, N3) correspondiente a cada tipo de falla (Ball, Inner, Outer y Normal) como se muestra en la ilustración 7. Por tal razón es de vital importancia generar dos tipos de etiqueta, y así obtener un análisis exacto para cada uno de los casos.

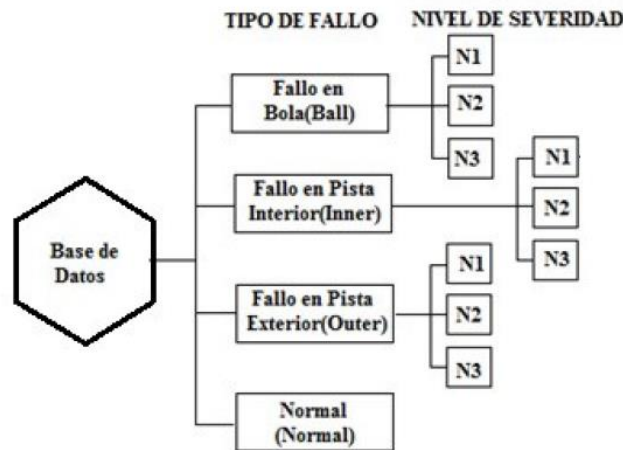


Ilustración 7 Distribucion de la base de datos

Para el primer análisis se etiquetará la base de datos según el tipo de falla, el cual se encuentra representado en las carpetas de la siguiente manera: Todo lo que pertenece a la carpeta de fallo en bola tendrá como etiqueta “1”, mientras que los datos almacenados en las carpetas de falla en pista interna, falla en pista externa y sin falla serán etiquetados como “2”, “3” y “4” respectivamente.

Luego se clasificara la base de datos mediante el nivel de severidad para posteriormente comparar con la clasificación obtenida mediante el tipo de falla. De esta forma se tendrá que la base de datos de la ilustración 7 estará clasificada en 10 clases diferentes

Fault Diameter	Motor Load (HP)	Approx. Motor Speed (rpm)	Inner Race	Ball	Outer Race Position Relative to Load Zone (Load Zone Centered at 6:00)		
					Centered @6:00	Orthogonal @3:00	Opposite @12:00
0.007"	0	1797	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1	1772	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	2	1750	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	3	1730	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0.014"	0	1797	IR014_0	B014_0	OR014@6_0	*	*
	1	1772	IR014_1	B014_1	OR014@6_1	*	*
	2	1750	IR014_2	B014_2	OR014@6_2	*	*
	3	1730	IR014_3	B014_3	OR014@6_3	*	*
0.021"	0	1797	IR021_0	B021_0	OR021@6_0	OR021@3_0	OR021@12_0
	1	1772	IR021_1	B021_1	OR021@6_1	OR021@3_1	OR021@12_1
	2	1750	IR021_2	B021_2	OR021@6_2	OR021@3_2	OR021@12_2
	3	1730	IR021_3	B021_3	OR021@6_3	OR021@3_3	OR021@12_3
0.028"	0	1797	IR028_0	B028_0	*	*	*
	1	1772	IR028_1	B028_1	*	*	*
	2	1750	IR028_2	B028_2	*	*	*
	3	1730	IR028_3	B028_3	*	*	*

Ilustración 8 Base de datos de 12K relacionados a fallas en rodamientos instalados en el extremo de la transmisión

Para el entrenamiento de la SVM el 70% de los datos de la ilustración 8 son utilizados de forma aleatoria, y se deja el 30% restante para las pruebas. Para realizar esto se diseñó un programa con el concepto del método de Monte Carlo y así garantizar que cada vez que se ejecute el programa tanto los datos de entrenamiento como los de prueba serán diferentes.

Para ejecutar la función de Monte Carlo en Matlab, es necesario ingresar la base de datos con la cual se desea entrenar la SVM, la tolerancia de la simulación y el número de clases. Posteriormente de forma aleatoria se entrega un 70% de los datos para la validación de la SVM, donde se puede hacer uso de la función Kernel, que puede ser Gaussiana, lineal o polinomial. Para este caso se simulara utilizando los tres casos, y así obtener una conclusión acerca de la mejor respuesta.

Luego llega el proceso de predicción de datos de entrenamiento con el 70% que entregó el método de Monte Carlo. Cuando ya se tiene la SVM entrenada, se utiliza el 30% de datos restantes y la máquina debe estar en la capacidad de clasificar a que clase pertenece cada uno de los datos de prueba.

Para escoger el porcentaje de entrenamiento y de prueba, el sistema toma el 30% de los datos de cada una de las carpetas, de esta forma garantiza que la selección de los datos de prueba no se van a encontrar desequilibrados ya que esto puede generar que los datos queden sobrecargados hacia una clase, y la SVM no pueda clasificar de forma adecuada.

Al ingresar los datos de prueba, la máquina procede a clasificar cada uno de los datos en una matriz de confusión. Ya que esta es la forma más eficiente de relacionar los datos que se clasificaron de forma correcta con los que se clasificaron de forma errónea.

2 RESULTADOS

En Matlab, se implementa el código para el entrenamiento de la SVM. Este código se encuentra diseñado para evaluar la base de datos utilizando tres funciones de Kernel diferentes (Gaussiano, línea y polinomial) por tal razón se procede a ejecutar el programa utilizando para cada caso los tres tipos de función iterando hasta que cumpla con el valor de la tolerancia y buscando encontrar la forma óptima de caracterizar la base de datos.

2.1 Clasificación de falla

Primero se ejecuta el programa utilizando como base de datos aquella que contempla todos los fallos en el rodamiento. Como fue mencionado en el capítulo anterior, el programa utiliza un 70%

de los datos para entrenar, y el 30 % restante para evaluar. A continuación se presenta el análisis obtenido para tipo de falla utilizando cada una de las funciones del Kernel. Las clases evaluadas en la SVM, son nombradas como C1, C2, C3, C4 donde:

- C1: Hace referencia a las fallas producidas en los elementos rodantes.
- C2: Representa las fallas en la pista interna del rodamiento.
- C3: Representa las fallas en la pista externa del rodamiento
- C4: Hace referencia al caso en el cual no existe tipo de falla en el rodamiento

2.1.1 Análisis mediante función Kernel Gaussiano para tipos de falla representados en cuatro clases

Se procede a simular en MatLab utilizando la función Kernel Gaussiano. Mediante El método de Monte Carlo se separa la base de datos de la forma que se menciona en el capítulo anterior, donde para cada tipo de falla la máquina selecciona el 70% para entrenar dejando libre el 30% para evaluar.

En la ilustración 9 se encuentra la matriz de confusión sin normalizar, donde es posible notar que la SVM clasifica de forma correcta todos los datos que fueron ingresados al sistema. Luego se procede a normalizar los datos de la matriz y graficar la matriz de confusión como se muestra en la ilustración 9 utilizando como datos los porcentajes de clasificación.



Ilustración 9 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Gaussiano

El valor de precisión de decodificación se calcula obteniendo la media de la diagonal de la matriz de confusión el cual para este caso equivale al 100%

2.1.2 Análisis mediante función Kernel Lineal para tipos de falla representados en cuatro clases

Se procede a simular por segunda vez, pero esta vez utilizando la función Kernel Lineal. Se observa en la ilustración 10 que igual que en el caso anterior el SVM clasifica de forma correcta el 30% de la base de datos que selecciona para pruebas.

Aunque la SVM clasifico los datos de la misma forma que en el caso anterior, al momento de normalizar se puede notar en la ilustración 10 que la matriz de confusión clasifica los datos de forma correcta, aunque para la clase 2 tuvo un VP del 99.92%. Esto afecta de una forma minima el valor de precisión de decodificación cambiando de 100% como en el caso del Kernel Gaussiano a un 99.97%.




Ilustración 10 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Lineal

2.1.3 Análisis mediante función Kernel Polinomial para tipos de falla representados en cuatro clases

Para este caso se realiza la simulación utilizando la función de Kernel polinomial, al igual que en los casos anteriores la forma de clasificación no varía, pero al momento de representar la matriz de confusión de forma porcentual se nota que esta vez la clase 1 “C1” obtuvo un VP de 99.54% lo cual garantiza una precisión de decodificación del 99.88%.




Ilustración 11 Matriz de Confusión para análisis de fallos utilizando como función un Kernel Polinomial.

2.2 Nivel de severidad

La segunda etapa de este trabajo de grado consiste en clasificar la base de datos mediante el nivel de severidad. Exceptuando los datos para el caso en que no existe falla (Normal), cada una de las fallas está compuesta por tres niveles de severidad, los cuales se encuentran representados en la matriz de confusión de la siguiente manera:

- BallN1: Base de datos para falla en el elemento rodante de la balinera (Bola) cuando se encuentra con nivel de severidad 1 (N1)

- BallN2: Base de datos para falla en el elemento rodante de la balinera (Bola) cuando se encuentra con nivel de severidad 2 (N2)
- BallN3: Base de datos para falla en el elemento rodante de la balinera (Bola) cuando se encuentra con nivel de severidad 3 (N3)
- InnerN1: Base de datos para falla en la pista interior de la balinera, cuando se encuentra en nivel de severidad 1 (N1)
- InnerN2: Base de datos para falla en la pista interior de la balinera, cuando se encuentra en nivel de severidad 2 (N2)
- InnerN3: Base de datos para falla en la pista interior de la balinera, cuando se encuentra en nivel de severidad 3 (N3)
- OuterN1: Base de datos para falla en la pista exterior de la balinera, cuando se encuentra en nivel de severidad 1 (N1)
- OuterN2: Base de datos para falla en la pista exterior de la balinera, cuando se encuentra en nivel de severidad 2 (N2)
- OuterN3: Base de datos para falla en la pista exterior de la balinera, cuando se encuentra en nivel de severidad 3 (N3)

Igual que en el caso anterior, se hace uso de Matlab para evaluar el proceso mediante cada tipo de kernel y así obtener los diferentes tipos de parámetros que puede arrojar el clasificador.

La base de datos se encuentra conformada por 12 datos para cada tipo de severidad. Para el caso en el que no hay falla igual que para las severidades también está compuesta por 12 datos.

2.2.1 Análisis mediante función Kernel Gaussiana

Se procede a simular la SVM, usando la función Kernel Gaussiana, donde, al analizar la base de datos, la función Monte Carlo se encarga de entrenar con el 70% de cada uno de los niveles de severidad, para garantizar de esta manera que al momento de probar con el 30% restante la máquina no esté sobrecargada hacia una de las clases.

En la ilustración 12 se observa la forma en que el programa clasifica los datos que utiliza para entrenamiento. Con una precisión de decodificación del 100% el programa clasifica de forma correcta obteniendo así solamente verdaderos Positivos.

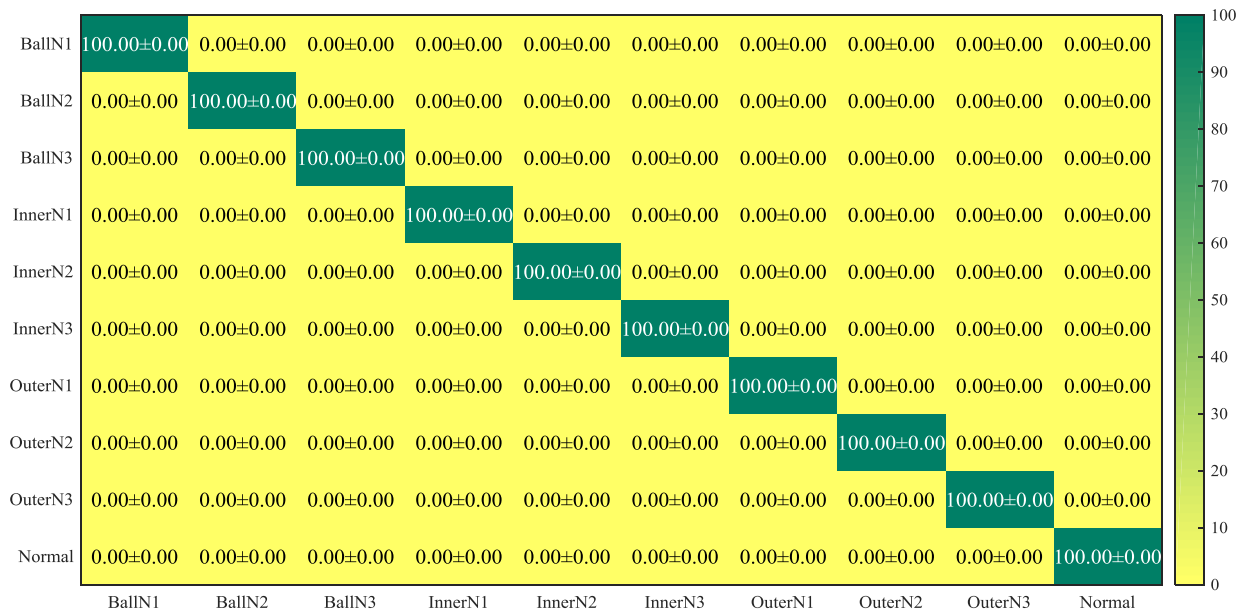


Ilustración 12 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Gaussiano

2.2.2 Analisis mediante función Kernel Lineal

Se simula nuevamente, pero para este caso utilizando la función Kernel Lineal. En la Matriz de confusión de la ilustración 13 se observa que igual que en el caso anterior el programa clasifica los niveles de severidad de forma correcta mostrando a su vez solamente verdaderos Positivos VP. Igual que para el caso anterior el programa hace uso del método de Monte Carlo para seleccionar de forma aleatoria el porcentaje utilizado para entrenar y evaluar.

Independientemente de que la maquina caracteriza todos los datos de forma correcta se puede notar en la matriz de confusion de la ilustración 13 que para el caso de falla en pista interna del rodamiento con nivel de severidad 2 (InnerN2) el sistema lo clasifica con una precisión del 99.57%. ya que el porcentaje restante lo asume como falla en elemento rodante de la balinera (Bola) para nivel de severidad 3 (BallN3).

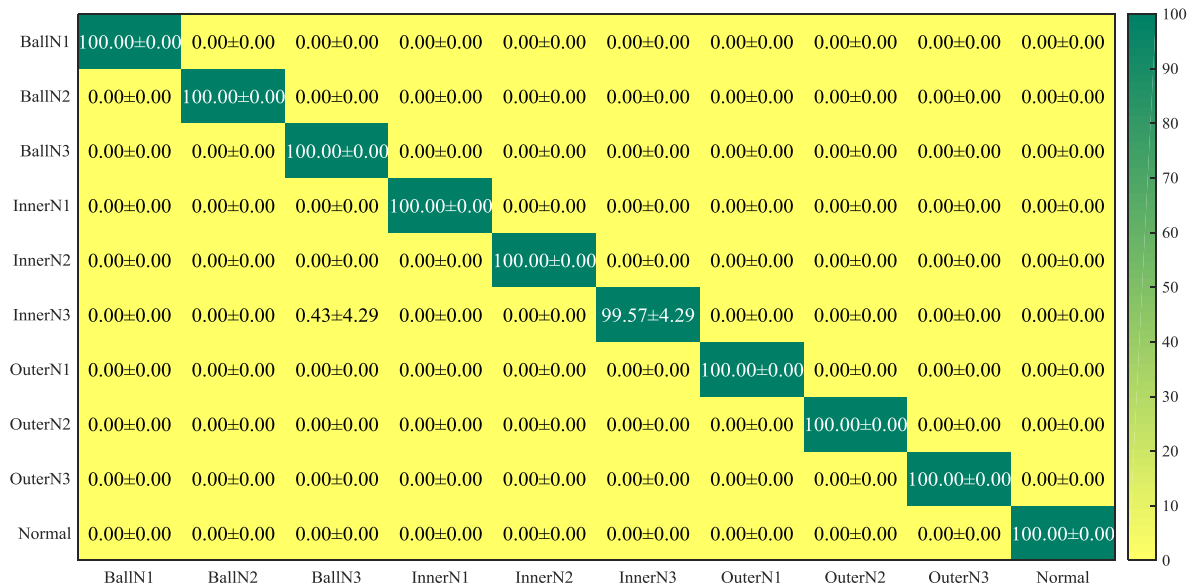


Ilustración 13 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Lineal

2.2.3 Análisis mediante función Kernel Polinomial

Para este caso se simula usando un Kernel Polinomial, después de continuas simulaciones el programa clasifica los datos de prueba igual que en los casos anteriores, como es notable en ilustración 14 donde se observa que a diferencia del caso anterior en este caso se obtiene una precisión del 99.60% para la falla en elemento rodante con nivel de severidad 3 (BallN3), asumiendo que el porcentaje restante pertenece a la clase InnerN2, caso contrario a los resultados anteriores.

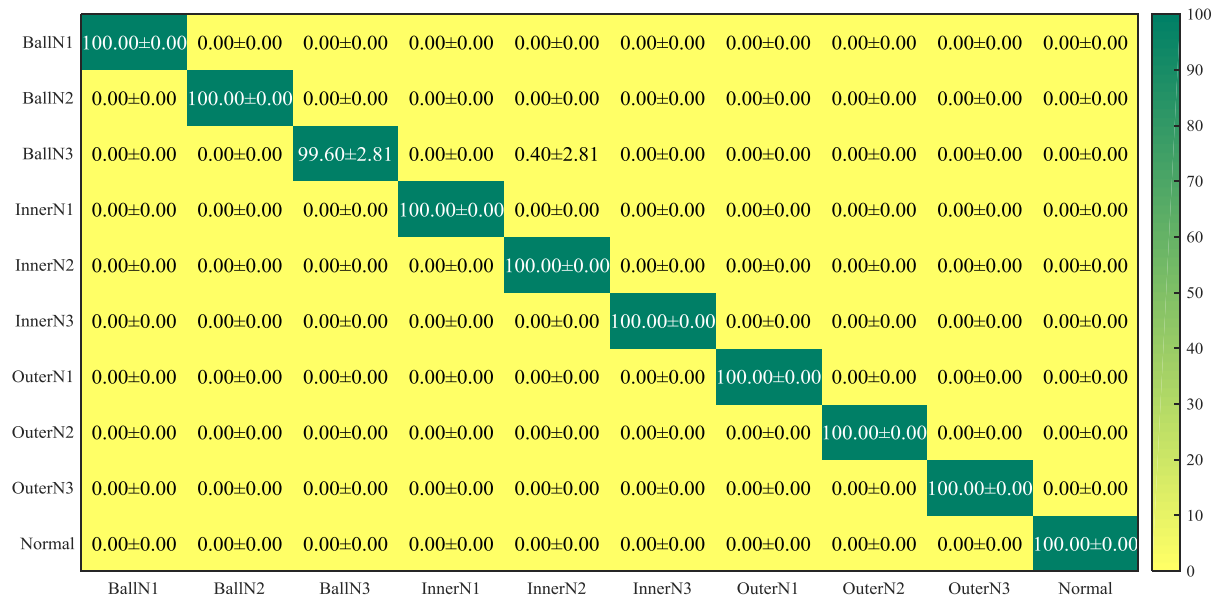


Ilustración 14 Matriz de Confusión para análisis de Niveles de severidad utilizando como función un Kernel Polinomial

De lo anterior se puede deducir que la sensibilidad con que la SVM clasifica la base de datos es del 100%. Caso contrario para la especificidad ya que los casos que pertenecen a verdaderos negativos son cero.

2.3 Clasificación del Nivel de severidad para cada tipo de falla.

Como proceso adicional se procede a analizar lo que sucede con la SVM al momento de analizar los datos de cada tipo de falla, obteniendo una clasificación independiente para los diferentes niveles de severidad.

2.3.1 Falla en bola

Se etiquetan los datos de falla en bola en tres clases basados en su nivel de severidad. Igual que en el caso anterior se selecciona un 70% para entrenar la SVM y el 30% restante es utilizado para la respectiva evaluación.

2.3.1.1 Analisis mediante función Kernel Gaussiana

Al simular la SVM, se obtienen resultados con características totalmente diferentes a las obtenidas en el caso de análisis de fallos. En la matriz de confusión de la ilustración 15 se puede visualizar la forma en la que es caracterizada la porción de la base de datos que se utilizó para la evaluación de la SVM. La simulación arroja que para este caso se tiene una precisión de decodificación del 96.46825%.




Ilustración 15 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Gaussiano

2.3.1.2 Análisis mediante función Kernel lineal

Igual que para el caso anterior se simuló la SVM, obteniendo como resultados las cantidades que se relacionan en la matriz de confusión de la tabla 8. Esta clasificación sigue la misma tipología del caso en que se usa la Función Kernel Gaussiano. En la matriz de la ilustración 16 se observa que la simulación arrojó que al momento de evaluar el programa utilizando la función de Kernel Lineal se obtiene una precisión de decodificación del 16.79%.




Ilustración 16 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Lineal

2.3.1.3 Análisis mediante función Kernel polinomial

La simulación de la SVM mediante la función del Kernel Polinomial es la última de las simulaciones realizada para el caso de nivel de severidad en fallas de bola. En la ilustración 17 se evidencia la Matriz de confusión mediante porcentajes de clasificación, con una precisión de decodificación de 83.35%.




Ilustración 17 Matriz de Confusión para análisis de niveles de severidad en falla de rodamiento utilizando como función un Kernel Polinomial

2.3.2 Falla en pista interna

Se repite el proceso realizado para la falla en bola, variando que para este caso se utilizan los datos que pertenecen a la falla de la pista interna del rodamiento. Estas simulaciones son realizadas bajo los mismos conceptos de porcentajes de datos para entrenamiento y evaluación. Los datos son etiquetados según el nivel de severidad, obteniendo tres clases de severidad al momento de realizar la matriz de confusión.

2.3.2.1 Análisis mediante función Kernel Gaussiano

En la ilustración 18 se encuentra relacionado la clasificación de los datos, luego de ejecutar el programa utilizando la función Kernel Gaussiano, para la base de datos que corresponde a la falla de la pista interna. Para esta clasificación se obtiene una precisión de decodificación de 55.57% el cual se obtiene haciendo uso de la matriz de confusión de la ilustración 18, donde se encuentran relacionados de forma porcentual los datos clasificados al momento de ejecutar la SVM.




Ilustración 18 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Gaussiano

2.3.2.2 Análisis mediante función Kernel lineal

Igual que para el caso anterior se simuló la SVM, obteniendo como resultados las cantidades que se relacionan en la matriz de confusión de la ilustración 19. Esta clasificación sigue la misma tipología de los casos anteriores.




Ilustración 19 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Lineal

2.3.2.3 Análisis mediante función Kernel polinomial

La simulación de la SVM mediante la función del Kernel Polinomial es la última de las simulaciones realizada para el caso de nivel de severidad en fallas en pista interna. En este caso como en todos los demás se utilizó un límite de 10.000 iteraciones para garantizar una adecuada precisión.

En la ilustración 20 se observa la clasificación del 30 % de los datos que para este caso el sistema separo para utilizar como prueba. Mientras que en la ilustración 31 se encuentran relacionados en forma porcentual la normalización de los datos caracterizados.




Ilustración 20 Matriz de Confusión para análisis de niveles de severidad de falla en cara interna utilizando como función un Kernel Polinomial

2.3.3 Falla en pista externa

Igual que para los casos anteriores se utiliza la base de datos que corresponde al tipo de falla de la pista externa. Posteriormente se simula la SVM utilizando también las diversas funciones kernel y etiquetando los datos según su tipo de severidad. De esta manera se procederá a realizar la matriz de confusión, tanto en unidades de datos sin normalizar, como el porcentaje de datos normalizados.

2.3.3.1 Análisis mediante función Kernel Gaussiana

En la ilustración 21 se encuentra relacionado la clasificación de los datos luego de ejecutar el programa mediante la función Kernel Gaussiano, para la base de datos que corresponde a la falla de la pista externa. Se obtiene una precisión de decodificación de 85.27%




Ilustración 21 Matriz de Confusión para análisis de niveles de severidad de falla en cara externa utilizando como función un Kernel Gaussiano

2.3.3.2 Analisis mediante función Kernel lineal

Se procede a cambiar la función del Kernel a lineal, y posteriormente ejecutar el programa, obteniendo como resultados las cantidades que se relacionan en la matriz de confusión de la ilustración 22 para una precisión de decodificación de 65.58%.




Ilustración 22 Matriz de Confusión para análisis de niveles de severidad de falla en cara externa utilizando como función un Kernel Lineal

2.3.3.3 Análisis mediante función Kernel polinomial

La ultima simulación corresponde al análisis realizado mediante la función Kernel Polinomial para clasificar el nivel de severidad en la cara externa del rodamiento. Igual que en los casos anteriores el programa entrega la clasificación de los datos (ver ilustración 23) y la clasificación en forma porcentual de las características normalizadas perteneciente a los niveles de severidad.




Ilustración 23 Matriz de Confusión para análisis de niveles de severidad de falla en cara externa utilizando como función un Kernel Polinomial

2.4 Análisis de los resultados obtenidos en la simulación de fallas y niveles de severidad

En este capítulo se procede a hacer el análisis para todos los casos vistos anteriormente. Empezando por los Falsos Negativos (FN) donde solo se obtiene un gran porcentaje para los casos relacionados al análisis de niveles de severidad realizados de forma independiente a las respectivas fallas. En este análisis se logra identificar el desbalance que tiene la máquina para clasificar ya que el 30% de los datos que usa para evaluar se encuentra en su mayoría mal clasificado.

Falsos Negativos (FN)				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	0	0	0
	C2	0	0	0
	C3	0	0	0
	C4	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	7	4	4
	C2	3	3	3
	C3	1	4	4
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	5	4	5
	C2	2	3	2
	C3	4	2	3
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	1	3	3
	C2	5	4	4
	C3	5	4	3
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	0	0	0
	BallN2	0	0	0
	BallN3	0	0	0
	InnerN1	0	0	0
	InnerN2	0	0	0
	InnerN3	0	0	0
	OuterN1	0	0	0
	OuterN2	0	0	0
	OuterN3	0	0	0
	Normal	0	0	0

Tabla 1 Representación de Falsos Negativos para todos los sistemas analizados

En los casos de nivel de severidad para todas las carpetas y análisis de fallas no se encuentran falsos negativos indicando que la SVM tuvo una buena clasificación de los datos utilizados para el test. Caso similar sucede para los análisis realizados a los diferentes datos sobre Falsos Positivos (FP) y Verdaderos Negativos (VN) identificados en las tablas 2 y 4 respectivamente, donde para tipos

de falla y niveles de severidad para todas las falla se identifica que no se encuentran valores relacionados garantizando una buena clasificación.

Falsos Positivos (FP)				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	0	0	0
	C2	0	0	0
	C3	0	0	0
	C4	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	3	4	4
	C2	4	3	3
	C3	4	4	4
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	3	2	2
	C2	4	4	4
	C3	4	3	4
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	4	3	4
	C2	4	4	4
	C3	3	4	2
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	0	0	0
	BallN2	0	0	0
	BallN3	0	0	0
	InnerN1	0	0	0
	InnerN2	0	0	0
	InnerN3	0	0	0
	OuterN1	0	0	0
	OuterN2	0	0	0
	OuterN3	0	0	0
	Normal	0	0	0

Tabla 2 Representación de Falsos Positivos para todos los sistemas analizados

Caso contrario Para los casos de niveles de severidad evaluados para los diferentes tipos de falla. Esto se debe a que para este análisis el programa cuenta con una base de datos pequeña y el sistema clasifica con una exactitud entre el 8 y el 16%, ocasionando una mala clasificación de los datos evaluados.

Verdaderos Positivos (VP)				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	11	11	11
	C2	11	11	11
	C3	11	11	11
	C4	4	4	4
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	1	0	0
	C2	0	1	1
	C3	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	1	2	2
	C2	0	0	0
	C3	0	1	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	0	1	0
	C2	0	0	0
	C3	1	0	2
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	4	4	4
	BallN2	4	4	4
	BallN3	4	4	4
	InnerN1	4	4	4
	InnerN2	4	4	4
	InnerN3	4	4	4
	OuterN1	4	4	4
	OuterN2	4	4	4
	OuterN3	4	4	4
	Normal	4	4	4

Tabla 3 Representación de Verdaderos Positivos para todos los sistemas analizados

En la Tabla 3 se encuentran relacionados los valores que pertenecen a la categoría de Verdadero Positivos para todos los casos analizados en este trabajo de grado. Al momento de analizar los tipos de falla y los niveles de severidad para todas las fallas se encuentra que el programa clasifica como Verdaderos Positivos a la totalidad de datos utilizados para entrenar la SVM. Pero cuando se analiza los niveles de severidad evaluados para los diferentes tipos de falla se nota que debido a la baja cantidad de datos que hay por cada tipo de falla el programa no logra clasificar de forma adecuada el 30% de los datos que había separado para pruebas.

Verdaderos Negativos (VN)				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	0	0	0
	C2	0	0	0
	C3	0	0	0
	C4	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	10	8	8
	C2	7	6	6
	C3	5	8	8
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	8	6	7
	C2	6	7	6
	C3	8	5	7
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	5	6	7
	C2	9	8	8
	C3	8	8	5
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	0	0	0
	BallN2	0	0	0
	BallN3	0	0	0
	InnerN1	0	0	0
	InnerN2	0	0	0
	InnerN3	0	0	0
	OuterN1	0	0	0
	OuterN2	0	0	0
	OuterN3	0	0	0
	Normal	0	0	0

Tabla 4 Representación de Verdaderos Negativos para todos los sistemas analizados

La sensibilidad, como se define en el capítulo 6.6 es la capacidad que tiene un sistema de clasificación de dar como datos positivos aquellos valores que en realidad pertenecen a esta clase. Partiendo de este concepto se puede verificar en la tabla 5 que la sensibilidad en los casos tipo de falla y nivel de severidad para todas las fallas es de 100%. Debido a que para estos casos la SVM clasifica de forma correcta todos los datos que fueron seleccionados para la prueba, mientras que para los niveles de severidad evaluados para cada tipo de falla la sensibilidad varía entre el 16% y 33% ya que cuando se analiza en los niveles de severidad para cada tipo de falla la SVM no clasifica de forma adecuado los datos de prueba, básicamente por que los datos que utiliza para entrenar son muy pocos, ocasionando que no logre identificar las características de todos los datos de prueba.

Sensibilidad				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	100%	100%	100%
	C2	100%	100%	100%
	C3	100%	100%	100%
	C4	100%	100%	100%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	12,5%	0	0
	C2	0	25%	25%
	C3	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	16,666667%	33,333333%	28,5714286%
	C2	0	0	0
	C3	0	33,333333%	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	0	25	0
	C2	0	0	0
	C3	16,666667%	0	40%
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	100%	100%	100%
	BallN2	100%	100%	100%
	BallN3	100%	100%	100%
	InnerN1	100%	100%	100%
	InnerN2	100%	100%	100%
	InnerN3	100%	100%	100%
	OuterN1	100%	100%	100%
	OuterN2	100%	100%	100%
	OuterN3	100%	100%	100%
	Normal	100%	100%	100%

Tabla 5 Representación de Sensibilidad para todos los sistemas analizados

La especificidad, es el caso contrario de la sensibilidad, ya que esta analiza la cantidad de datos que fueron seleccionados de forma errónea por la SVM. En la tabla 6 se encuentra plasmado el análisis de especificidad realizado a todas y cada una de las clases que se evalúan en este proyecto de grado. De aquí cabe resaltar que solo se presenta, y en alto porcentaje, la especificidad para el caso de Esto por el hecho de que fue el caso en los que la SVM clasifica de forma errónea los datos de prueba.

El accuracy o exactitud independientemente de la función Kernel con la que se evalúa varía según el caso en el que se utiliza. Para los tipos de falla y niveles de severidad de todas las fallas se encuentra que la SVM clasifica con un accuracy del 100%. Mientras que para los otros casos se obtienen unos porcentajes de exactitud muy bajos los cuales varían entre 8% y 25%. Representando de esta forma una mala clasificación.

Especificidad				
	CLASE	FUNCIÓN KERNEL		
		GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	C1	0	0	0
	C2	0	0	0
	C3	0	0	0
	C4	0	0	0
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	C1	76,9230769%	66,666667%	66,666667%
	C2	63,6363636%	66,666667%	66,666667%
	C3	55,5555556%	66,666667%	66,666667%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	C1	72,7272727%	75%	77,777778%
	C2	60%	63,636364%	60%
	C3	66,666667%	62,5%	63,6363636%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	C1	55,5555556%	66,666667%	63,6363636%
	C2	69,2307692%	66,666667%	66,666667%
	C3	72,7272727%	66,666667%	71,4285714%
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	BallN1	0	0	0
	BallN2	0	0	0
	BallN3	0	0	0
	InnerN1	0	0	0
	InnerN2	0	0	0
	InnerN3	0	0	0
	OuterN1	0	0	0
	OuterN2	0	0	0
	OuterN3	0	0	0
	Normal	0	0	0

Tabla 6 Representación de Especificidad para todos los sistemas analizados

Accuracy			
	FUNCIÓN KERNEL		
	GAUSSIANO	LINEAL	POLINOMIAL
TIPOS DE FALLAS	100%	100%	100%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN BOLA	8,33333333%	8,33333333%	8,33333333%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA INTERNA	8,33333333%	25%	16,6666667%
NIVEL DE SEVERIDAD EVALUADO PARA FALLA EN PISTA EXTERNA	8,33333333%	8,33333333%	16,6666667%
NIVEL DE SEVERIDAD PARA TODAS LAS FALLAS	100%	100%	100%

Tabla 7 Representación de Accuracy para todos los sistemas analizados

3 CONCLUSIONES

- La realización de diseños de muestreo y análisis estadísticos se puede tornar como un ambiente tedioso, debido a que se debe de partir de unos datos supuestos. En la actualidad existen muchas herramientas para obtener un proceso de validación. Debido a la exactitud que se obtiene mediante estos métodos los tiempos de simulación se vuelven largos y costosos en recursos informáticos. Por tal razón después de estudiar los diferentes esquemas de entrenamiento de máquina tipo jerárquico basados Máquinas de Soporte Vectorial (SVM), se llega a la conclusión en este trabajo de grado que es un esquema de entrenamiento óptimo y económico en recursos, debido a que mientras en los otros esquemas de entrenamiento se hace uso de modelos ocultos para transformar espacios de cualquier dimensión, en la SVM se hace uso de la función denominada Kernel tipo lineal, logarítmica o exponencial transformar estos espacios a una dimensión superior optimizando mediante un entrenamiento eficiente los tiempos al momento de la iteración.
- Se hace uso de diferentes espacios de representación como el tiempo debido a que es la representación natural de una señal de vibración, la frecuencia gracias a su fácil análisis espectral, tiempo – frecuencia por ser la forma más viable para encontrar la energía de los puntos del sistema perteneciente a las señales de vibración obtenidas mediante la base de datos generadas en el centro de datos de rodamiento de Case Western Reserve University. Se obtienen los coeficientes cepstrales de la base datos debido a que es la mejor forma de extraer las características de las componentes de las señales de vibración y así identificar de forma relevante el contenido de estas señales para una adecuada caracterización al momento de entrenar la SVM.
- Se implementa el esquema jerárquico usando como observaciones las características desde diversos espacios de representación clasificando estados de degradación de rodamientos mediante el uso de SVM, donde se encuentra que este método posee grandes cualidades en la generalización con respecto a ciertas cantidades de muestra obteniendo un gran rendimiento en la caracterización de datos en diferentes entornos de análisis lineales y no lineales, con altos niveles de confiabilidad en el diagnostico de fallas para los diferentes tipos de clases evaluadas.
- En la aplicación de este modelo se obtiene una exactitud del 100% lo cual muestra que es mejor tener SVM de forma jerárquica para predecir tanto el tipo de fallo como el nivel de degradación en los rodamientos, debido a la confiabilidad en el diagnostico de fallos, cuando se tiene una cantidad de datos reducida. Este procedimiento permite detectar de forma rápida posible fallos en los rodamientos.

4 BIBLIOGRAFIA

- [1]. D. Q. Phung, S. Venkatesh, and H. H. Bui, "Automatically learning structural units in educational videos with the hierarchical hidden Markov models," in *Image Processing, 2004. ICIP'04. 2004 International Conference on*, 2004, pp. 1605-1608.
- [2]. M. Holguin., A. A. Orozco .Angel., and M.Alvarez., "FUSIÓN Y SELECCIÓN DE ESPACIOS DE REPRESENTACIÓN Y SUS CARACTERÍSTICAS EN TIEMPO, FRECUENCIA Y TIEMPO-FRECUENCIA, PARA DIAGNÓSTICO DE MODOS DE FALLO Y SEVERIDAD EN RODAMIENTOS, USANDO HMM," in *12º CONGRESO IBEROAMERICANO DE INGENIERÍA MECÁNICA*, Guayaquil, 2015.
- [3]. F. J. O. Quijano, J. J. P. González, and J. E. Q. Méndez, "Clasificador difuso de señales de vibración para monitoreo de rodamientos," *Revista de Ingeniería*, pp. 20-26, 2011.
- [4]. L. R. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings of the IEEE*, vol. 77, pp. 257-286, 1989.
- [5]. B. Tang, T. Song, F. Li, and L. Deng, "Fault diagnosis for a wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine," *Renewable Energy*, vol. 62, pp. 1-9, 2014.
- [6]. D. Tobon-Mejia, K. Medjaher, N. Zerhouni, and G. Tripot, "Hidden Markov models for failure diagnostic and prognostic," in *Prognostics and System Health Management Conference (PHM-Shenzhen), 2011*, 2011, pp. 1-8.
- [7]. H. Ocaik and K. A. Loparo, "A new bearing fault detection and diagnosis scheme based on hidden Markov modeling of vibration signals," in *Acoustics, Speech, and Signal Processing, 2001. Proceedings. (ICASSP'01). 2001 IEEE International Conference on*, 2001, pp. 3141-3144.
- [8]. A. Soualhi, H. Razik, G. Clerc, and D. D. Doan, "Prognosis of bearing failures using hidden Markov models and the adaptive neuro-fuzzy inference system," *Industrial Electronics, IEEE Transactions on*, vol. 61, pp. 2864-2874, 2014.
- [9]. S. Fine, Y. Singer, and N. Tishby, "The hierarchical hidden Markov model: Analysis and applications," *Machine learning*, vol. 32, pp. 41-62, 1998.
- [10]. H. H. Bui, D. Q. Phung, and S. Venkatesh, "Hierarchical hidden Markov models with general state hierarchy," in *Proceedings of the National Conference on Artificial Intelligence*, 2004, pp. 324-329.
- [11]. H.-E. Kim, A. C. Tan, J. Mathew, and B.-K. Choi, "Bearing fault prognosis based on health state probability estimation," *Expert Systems with Applications*, vol. 39, pp. 5200-5213, 2012.
- [12]. G. A. Betancourt, "Las máquinas de soporte vectorial (SVMs)," *Scientia et Technica*, vol. 1, 2005.
- [13]. G. Mosquera, M. V. Piedra Diaz, R. A. Armas Cardona, "Las vibraciones mecánicas y su aplicación al mantenimiento predictivo" *Centro de Altos Estudios Gerenciales, Instituto Superior de Investigación y desarrollo*. Caracas 2001.
- [14]. J. J. Piñeyro, A. E. Klempnow, "Análisis y diagnóstico de fallas en un rodamiento que opera a bajas vueltas." *IV Conferencia panamericana de END*. Buenos Aires. Octubre 2007.
- [15]. A. M. Castellino, P. D. Donolo, G. R. Bossio, C. H. De Angelo, G. Cordoba. "Diagnóstico de fallas en los rodamientos de motores eléctricos empleando variables eléctricas" Grupo de

- Electrónica aplicada , Fac. de Ingeniería Universidad Nacional de Río Cuarto Ruta Nac.#36 Km 601, (X5804BYA), Río Cuarto. Córdoba, Argentina.
- [16]. Koyo, JTEKT. “Fallas en los rodamientos, causas y contramedidas.” *Manual de rodamientos, Mantenimiento fallas y ddesignaciones*. Foll. 123 Sp, Febrero 2010.
 - [17]. D. F. Medina. “Evaluación de metodologías para el diagnóstico automatizado de la severidad de fallas, apartir de vibraciones mecánicas en rodamientos, usando características de tiempo y de frecuencia, con Modelos Ocultos de Márkov.” *Proyecto presentado como requisito parcial para optar al título de Ingeniero Electricista, Univeridad Tecnológica de Pereira, Facultad de Ingeniería Eléctrica, Pereira, Risaralda, Colombia, 2013.*
 - [18]. L. Sanzol, P. Martinez. “IMPLANTACIÓN DE PLAN DE MANTENIMIENTO TPM EN PLANTA DE COGENERACIÓN” *Proyecto presentado como requisito parcial para optar al título de Ingeniero Técnico Industrial Mecánico, Escuela técnica superior de ingenieros industriales y de telecomunicación, Pamplona, 15 de septiembre de 2010.*
 - [19]. J. L. Marrero García, “Fallas que presentan los cojinetes, durante el período de vida útil” *Universidad central Marta Abreu de las veritate sola Nobis Imponetur virilistoga. 2015*
 - [20]. Y. A. CastroMartinez,”Banco experimental para estudios de fallas en rodamientos mediante análisis de vibraciones” *Universidad industrial de Santander, Bucaramanga, 2008.*
 - [21]. Partesdel.com. “Partes del rodamiento” <https://www.partesdel.com/rodamiento.html>, junio de 2018
 - [22]. P. Aristizabal. “Metodología para caracterizar señales de vibración en motores diésel, usando representaciones del Tiempo, Frecuencia y Tiempo-Frecuencia y diagnóstico mediante HMM” *Proyecto presentado como requisito parcial para optar al título de Ingeniero Electricista, Univeridad Tecnológica de Pereira, Facultad de Ingeniería Eléctrica, Pereira, Risaralda, Colombia, 2016.*
 - [23]. B. Balachandran, Edward. B. “Vibraciones” *Edición Thomson, 2016, ISBN 9706864954.*
 - [24]. R. A. Mendoza. León. “Método de inferencia estadística para entrenamientode modelos ocultos de Markov” *politécnico Grancolombiano, Revista Elementos – Número 1, junio de 2011*
 - [25]. J. M. Vuletich, A. M. C. Ruedin. “NUEVAS BASES PARA EL PROCESAMIENTO DE MÚSICA EN EL DOMINIO DE TIEMPO-FRECUENCIA” *Departamento de computación, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Buenos Aires,2005.*
 - [26]. A. Ben-Hur, J. Weston. “A User’s Guide to Suport Vector Machine” *Department of computer Science, Colorado State University.*
 - [27]. E. J. Carmona Suárez. “Tutorial sobre Máquinas de Vectores Soporte (SVM)” *Dto de Inteligencia Artificial, ETS de Ingenieria Informatica, Universidad Nacional de Educación a Distancia (UNED). C/Juan del Rosal , 16-28040-Madrid (Spain).*
 - [28]. Andrew Ng. “Suport Vector Machines” *CS229 Lecture notes, Parte V*
 - [29]. L. Wang. “Support Vector Machines: Theory and applications” *Sprnger, Berlin, 2005*
 - [30]. D. Wisniewski, W. Wawrzyniak, “Support vector machines” *curso de entrenamiento de maquinas de soporte vectorial.*

- [31]. Gestal, M., Rivero, D., Rabuñal, J. R., Dorado, J., & Pazos, A. (2010). Introducción a los Algoritmos genéticos y la Programación genética. A Coruña, 2010, 30-68.
- [32]. Delgado, E., Castaño, A. M., Godino, J. I., & Castellanos, G. (2008, January). Detección de soplos cardiacos usando medidas derivadas del Análisis Acústico en señales fonocardiográficas. In IFMBE PROCEEDINGS (Vol. 18, No. 1, p. 202). SPRINGER SCIENCE+ BUSINESS MEDIA.
- [33]. A. L. Schmidt. “FFT: Transformada Rápida de Fourier” *Estudiante de Ingenieria en Sistemas de Computación. Universidad Nacional de Sur. Bahia Blanca, Argentina. Marzo 2013*
- [34]. Seeded Fault Test Data. Bearing Data Center.” <http://csegroups.case.edu/bearingdatacenter/pages/download-data-file>” Case Western Reserve University.
- [35]. J.JGómez Cadenas “El Método de Monte Carlo.” *Curso de estadística, TAE, 205*
- [36]. <https://csegroups.case.edu/bearingdatacenter/pages/download-data-file>